

Deep 畳み込みニューラルネットワークによる実験データ分類の事例研究

Case study of data classification using deep convolutional neural networks

立命館大学 谷口元希, 瀬尾昌孝, 西川郁子

Genki Taniguchi, Takamasa Seo and Ikuko Nisikawa

Ritsumeikan University

Abstract Deep learning has been successfully used for various pattern classification tasks based on its learning ability to extract the features. The present report applies a deep convolution neural network (DCNN) for biological data expressed as two-dimensional image data. Receptive field of auditory neuron in rat midbrain is acquired from a spectro-temporal histogram, which is obtained as spike-triggered average (STA) of auditory stimulus with random frequency modulation. Such spectro-temporal receptive field (STRF) of each neuron is expressed as a gray scale image data, and input to DCNN for the classification. Receptive field of each neuron is classified into three classes, which is close to a subjective classification done by a physiological experimentalist.

1 はじめに

人間には容易なパターン分類課題も、従来の分類手法では、分類対象をまず特徴量で表現し直す必要があり、有効な特徴量を得ること自体が課題であったが、深層学習では特徴量をデータから学習することで高い分類性能を上げる例が多く報告されている。本報告では、生物実験データに対して実験家が経験に基づく主観評価によって行った分類を、深層学習などの機械学習でも再現できるかを実験した。そこでの実験家は、特徴量を明示的に示すことはなく、データの分類結果のみを示す。学習器がそれを学習できれば、共通の分類基準ができるだけでなく、分類境界の存在が分かり、また分類の特徴量を得ることで、生体の機能や形態に対応付けたデータの理解に繋がる可能性もある。

事例研究として、ラットの聴覚ニューロンの生理学実験データを用いる。ここでは特に、周波数変調する聴覚刺激に反応するニューロンに着目し、その反応特性を周波数と時間の二次元空間における受容野として特徴付ける。各ニューロンの受容野を表す二次元画像を用いて、そのパターンのみから画像分類を行うことでニューロンを分類する。まず、画像データについて次節で説明する。

2 聴覚ニューロンの受容野

感覚ニューロンの受容野は、視覚ニューロンに対して最もよく研究され知見が蓄積されている。ある視覚ニューロンが視覚入力刺激を受けてスパイク発火するとき、発火時点までの入力の時間特性と、入力の空間特性を合わせることで、入力刺激の時空間における時空間受容

野 (spatio-temporal receptive field) を考えることができる。そのニューロンを発火に至らしめる刺激であり、ニューロンの機能の特徴付ける [1]。

聴覚ニューロンに対しても同様に、聴覚刺激である音入力を受けてスパイク発火をするとき、発火時点までの音の時間特性と、音の周波数特性を合わせることで、入力刺激の周波数-時間における受容野 (spectro-temporal receptive field: STRF) を考えることができる。それを実験的に得るために、時間的に周波数が変化する音刺激 (frequency modulation: FM 入力) をランダムに与え、ニューロンがスパイク発火した時刻をトリガーとして刺激を平均して spike-triggered average (STA, reverse correlation と呼ばれる) を得る。視覚刺激を空間的に広がった各画素に与える場合には時間的に無相関となるようランダムに与えることができるが、音刺激の周波数は、時間的に無相関にすることは厳密には不可能であり、全刺激の平均が一定となるように与えることも困難なため注意が必要である。ここでは特に、スパイク時刻をトリガーにして、スパイクを発生した全刺激の平均から、与えた全刺激の平均を減算して STA とした。

以下では、ラットの中脳の聴覚ニューロンに対してランダム FM 刺激を与えて得られた STA を取り扱う。中脳は、蝸牛で受けた聴覚刺激を大脳皮質に伝達する前の段階に相当するため、特定の周波数にのみ反応する有毛細胞からの情報を統合し、より複雑な周波数特性に反応するが、大脳皮質ニューロンより反応時間は短い。スパイク前の 40 ミリ秒からスパイク後 10 ミリ秒の計 50 ミリ秒を切り出し、周波数領域はそのニューロンがスパイク反応する範囲をカバーするよう実験を行った。STA は

図 2, 3 に見られるモノクロ濃淡画像として表される．図では横軸が 50 ミリ秒間の時間に対応し，縦軸は周波数であり，対象とした全ニューロンで規格化し十分広い周波数領域をとった．濃淡で表された刺激頻度は白が高周波度であり，図中の白い領域がそのニューロンの受容野に相当する．すなわち，白色領域で示される周波数-時間特性の刺激に対してニューロンはスパイク応答を示す．

3 DCNN による受容野の分類

各種の画像分類で有効性が報告されている深層畳込みニューラルネットワーク (deep convolutional neural network, DCNN) を用いて，STA 画像を分類する．ここでは手書き数字分類のために提案された LeNet を用いる [2]．畳込み層とプーリング層を 2 つずつ持つ．

DCNN への入力はいずれも各ニューロンの STA に相当する画像であり，95 ニューロンから得られた画像計 95 枚を用いた．ネットワークの規模に対して非常に少ないデータ数だが，同じ脳内部位の聴覚ニューロンに対する網羅的な実験データとしては他に類を見ない数であり，今回機械学習を用いた理由でもある．また，プーリング層を持たない畳込みネットワークでの予備実験では，学習ができなかった．

このデータに対して実験家は，受容野の形状に応じて次の 3 クラスに分類し各クラスの特徴を議論している：下降 (falling)，上昇 (rising) と混合 (mixed) であり，時間に伴う周波数の変調で分けているが，mixed は同時に周波数が変化しないトーン (tone) 刺激にも応答することが別の実験で分かっているもので，用いた STA のみからは判別できないものも含まれている．95 データ中，上記の 3 クラスにそれぞれ 26, 34 および 35 データ含まれている．各クラスから 5 データを評価用とし，残りのデータを学習に用いた．

5 データを 1 バッチとした 1000 回の学習過程を図 1 に示す．300 回目以降は評価データに対する誤差が増加しており，データ数の少なさから過学習となっている．そこで，300 回時点で学習を止め，評価データに対する出




図 1: LeNet を用いた分類の学習曲線

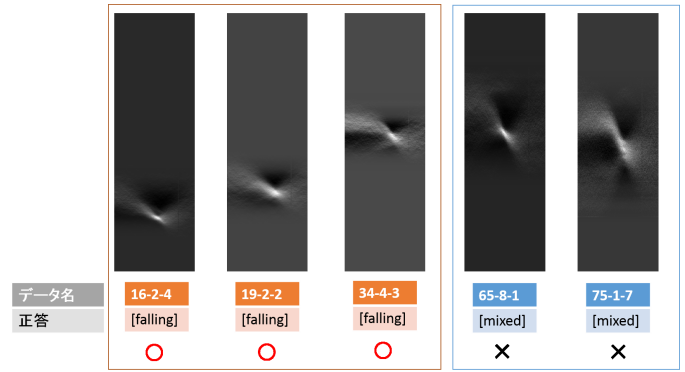


図 2: 評価用 falling データに対するネットワーク出力

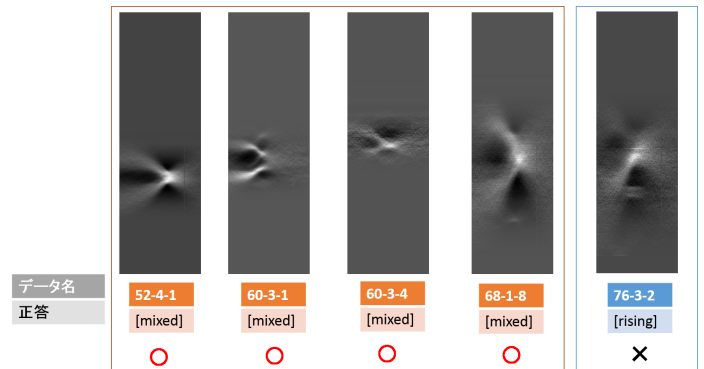


図 3: 評価用 mixed データに対するネットワーク出力

力を求めた．falling および mixed クラスの評価データ画像とネットワーク出力を図 2 および図 3 に示す．誤答数はそれぞれ 2 と 1 であり，目視で判別しにくいデータにも見える．rising に対しては，いずれも正答した．

全体の正答率は 8 割で，実験家の説明に基づき他者が分類した場合と同等であった．特に画像のみからは基準が分かりにくい mixed クラスが性能を落とした．

4 おわりに

ここでは生理学実験データに対する実験家の主観評価を対象に機械学習を行い，その再現性から分類基準の再評価を試みた．学習結果を主観評価者にフィードバックすることで，より客観性の高い基準の設定や，機能的理解にも結び付くことを期待したい．

参考文献

[1] S. Nishimoto, T. Ishida and I. Ohzawa: Receptive field properties of neurons in the early visual cortex revealed by local spectral reverse correlation.; J Neuroscience, 26(12), 3269-80, (2006).

[2] Yann le Cun: Generalization and Network Design Strategies; Technical Report CRG-TR-89-4,(1989).